

ОБЗОР АНСАМБЛЕВЫХ МЕТОДОВ ПРОГНОЗИРОВАНИЯ НА ПРИМЕРЕ АКТИВОВ ЭНЕРГЕТИЧЕСКИХ КОМПАНИЙ¹

Иванюк В.А., Петросов Д.А., Михайлов А.Ю.,

Финансовый университет при Правительстве Российской Федерации, Москва, Россия
VAIvanyuk@fa.ru

Цвиркун А.Д., Шувалов К.И.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия
tsvirkun@ipu.ru, shuval@ipu.ru

Аннотация. Поскольку мир становится все более зависимым от данных, прогнозирование временных рядов стало важным инструментом для предсказания будущих значений переменной на основе прошлых наблюдений. Прогнозы, обеспечивающие точность помогают принимать обоснованные решения инвесторам, трейдерам и финансовым организациям, это позволяет им получать значительные преимущества на рынке. В последние годы все большее внимание уделяется ансамблевым методам прогнозирования, объединяющим прогнозы нескольких моделей для повышения точности и устойчивости конечного прогноза.

Ключевые слова: ансамблевые методы прогнозирования, моделирование, временные ряды.

Введение

Прогнозирование будущих значений финансовых временных рядов основывается на анализе текущих данных и включает в себя процесс определения тенденций и всевозможных событий, которые могут повлиять на прогнозируемые значения. Для осуществления данного процесса используются различные методы, которые имеют разные классификации.

В зависимости от типа данных можно классифицировать методы прогнозирования следующим образом:

- а) статистические методы
- б) экспертные методы, которые основаны на опыте и знаниях экспертов в конкретной области.
- в) авторегрессионные методы
- г) методы машинного обучения и искусственного интеллекта
- д) ансамблевые методы

1. Анализ методов прогнозирования

Статистические методы, основываются на регрессионных методах анализа. Экспертные методы, которые основаны на опыте и знаниях экспертов в конкретной области включают в себя методы экспертных оценок, такие как метод анализа иерархий, метод Дельфи и другие.

Рассмотрим авторегрессионные методы, которые имеют такие преимущества при использовании их в прикладных моделях, как гибкость и последовательность анализа. Однако, эти модели не свободны от недостатков, таких как неоднозначность оцениваемых коэффициентов и сложность их оценки.

Авторегрессионные модели прогнозирования предполагают, что величина процесса $Y(t)$ линейно зависит от некоторого числа предшествующих значений данного процесса. Составление краткосрочных прогнозов при большом количестве наблюдений с использованием данного метода позволяет с высокой долей точности строить прогнозы. Существует несколько методов авторегрессии, которые различаются используемыми коэффициентами и показателями при прогнозировании значений. Самой актуальной моделью является ARIMA.

Модель можно записать в виде ARIMA(p, d, q), где p, d, q – неотрицательные целые числа, являющиеся порядком для каждой компоненты ряда. Для временного ряда X модель записывается в виде:

$$(\Delta^d x_t) = \mu + \sum_{t=1}^p \varphi_t (\Delta^d x_{t-1}) + u_t + \sum_{j=1}^q \theta_j (\Delta^d u_{t-j}), \quad (1)$$

где: Δ^d – оператор разности порядка d;
 φ_t – коэффициенты авторегрессионной модели;

¹ РНФ 23-41-10001 «Математические модели и компьютерные технологии календарного планирования производства и энергетики в условиях экономической неопределённости». Руководитель: Михайлов А.Ю. Исполнитель: Иванюк В.А.

u_t – значения ошибки, на которые накладывается предположение о независимости и принадлежности нормальному распределению с нулевым математическим ожиданием;

θ_j – коэффициенты модели скользящего среднего.

Однако модель ARIMA не является самым эффективным способом предсказания развития временного ряда, так как точность прогнозирования данной модели резко ухудшается при увеличении горизонта прогнозирования.

Метод экспоненциального сглаживания (exponential smoothing) – это сравнительно простой и эффективный метод прогнозирования, который использует взвешенное среднее значение прошлых наблюдений для предсказания будущих значений.

Методы экспоненциального сглаживания обобщают метод скользящего среднего, их основу составляет концепция постоянного обновления прогнозных значений по мере появления фактических. Они наиболее эффективны при составлении среднесрочных прогнозов параметров тренда и выявлении тенденции.

В последние годы все больше популярности набирают нейронные сети, применение которым находится практически в каждой области деятельности человека. Существует довольно много вариантов построения нейронной сети. Самый простой алгоритм был придуман еще в 1960-х годах и называется перцептрон.

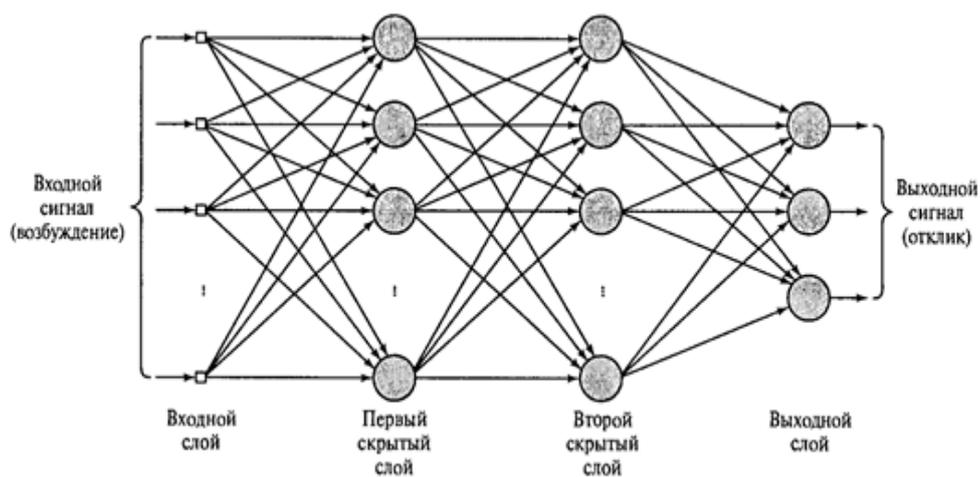


Рис. 1. Структура многослойного перцептрона

Основные элементы перцептрона: нейроны, веса, смещения и функция активации. Нейроны – основные строительные блоки перцептрона, которые имитируют работу нейрона в мозге человека. Они принимают информацию, обрабатывают ее и передают дальше по сети.

В перцептроне нейроны организованы в различные слои. Каждый слой состоит из набора нейронов, которые выполняют определенные функции и передают информацию между собой. Входной слой – первый слой перцептрона, который принимает входные значения и передает их в следующий слой. Результаты обработки передаются следующему слою нейронов. Последний слой перцептрона – выходной слой. Он получает информацию от последнего скрытого слоя и на выходе передает окончательные данные.

1.1. Ансамблевые методы

Рассмотрим методы ансамблирования временных рядов:

— бэггинг. На основе алгоритма бэггинга создаются выборки данных и модель обучается на каждой из этих выборок. Результаты моделей суммируются для вывода финального прогноза, обычно путем усреднения или голосования;

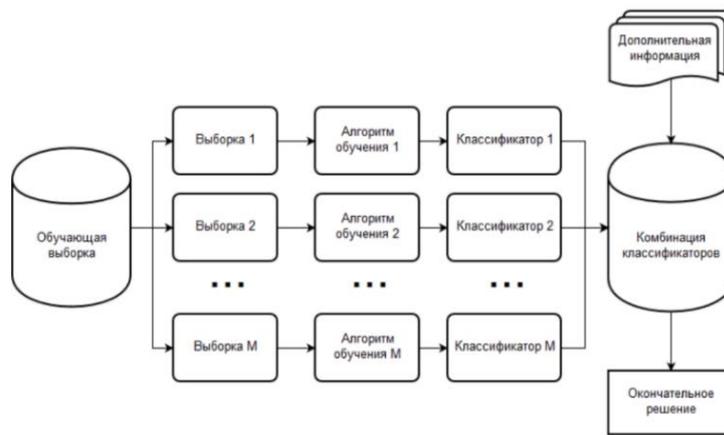


Рис. 2. Алгоритм бэггинга

— бустинг (boosting). Данный метод заключается в последовательном обучении ансамбля моделей, где каждая последующая модель стремится исправить ошибки предыдущих. В отличие от бэггинга, где обучение моделей происходит независимо, бустинг стремится добавлять новые модели, которые улучшают слабые места ансамбля.

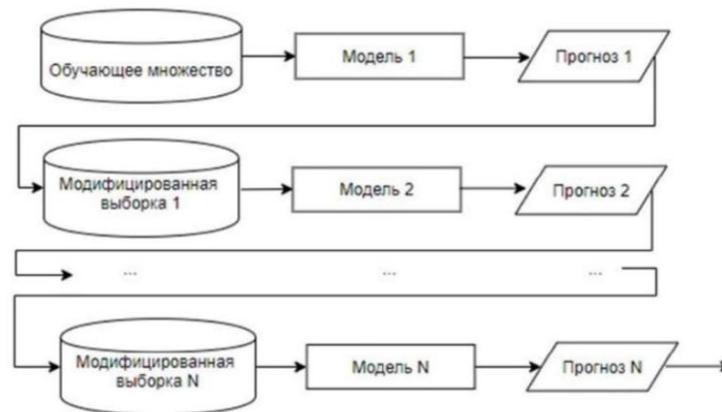


Рис. 3. Алгоритм бустинга

— стекинг (stacking). Данный метод включает в себя слои различных моделей, которые обучаются независимо, и мета-модель, которая использует их предсказания как признаки для создания финального прогноза. Это позволяет комбинировать сильные стороны различных моделей и уменьшить их слабые стороны. Таким образом, по методике стекинга есть 2 типа моделей. Первый – это Level-0 Models (Base-Models), которые являются независимыми моделями различного типа, их предсказания используются как признаки для следующего уровня. Второй тип – это Level-1 Model (Meta-Model), который делает окончательное предсказание на основе анализа базовых моделей.

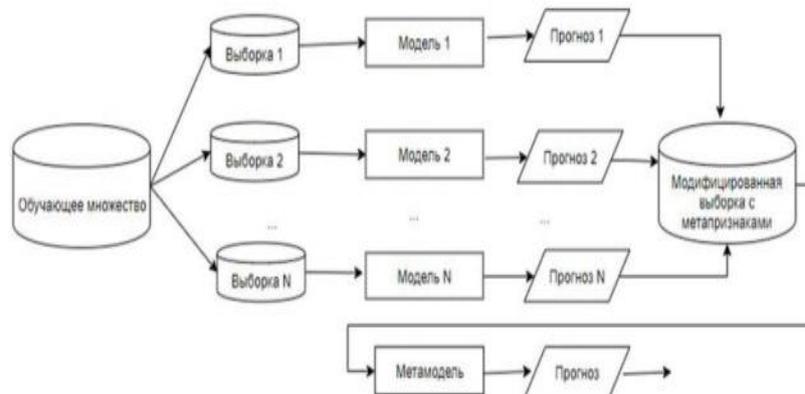


Рис. 4. Алгоритм ансамблирования стекинг

— взвешивание моделей. Поэтапно происходит: оценка точности каждой модели на валидационном наборе данных; присвоение весов моделям на основе их производительности; комбинирование предсказаний моделей, умноженных на их веса, для получения финального прогноза.

Ансамблевые методы – это мощные инструменты в машинном обучении, которые могут значительно улучшить производительность моделей, особенно в сложных задачах прогнозирования. Они могут уменьшить различные типы ошибок: бэггинг уменьшает вариативность, бустинг – смещение, а стекинг – обе проблемы, интегрируя разнообразные модели. Правильно используя эти методы, можно достичь высокой точности и устойчивости в прогнозах.

В задачах регрессии для оценки качества построенного предсказания моделью используются различные метрики

Среднеквадратичная ошибка:

$$MSE(y^{true}, y^{pred}) = \frac{1}{N} \sum_{i=1}^N (y_i - f(x_i))^2. \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - f(x_i))^2} \quad (3)$$

2. Примеры составления ансамблей прогнозов

Приведем пример составления ансамблей прогнозов. Для прогнозирования финансовых временных рядов были выбраны следующие методы анализа: ARIMA и нейронные сети LSTM и CNN. Также реализована гибридная взвешенная ансамблевая модель данных методов. Для прогнозирования был выбран энергетический сектор России, такие акции как Акрон, Лукойл, Газпром. Исходные данные по акциям были подготовлены и обработаны. Данные взяты с 16 октября 2006 г. до 27 февраля 2023 г. с сайта «<https://www.finam.ru>». На их основании были построены графики и прогнозы, примеры представлены на рисунках 5 – 7

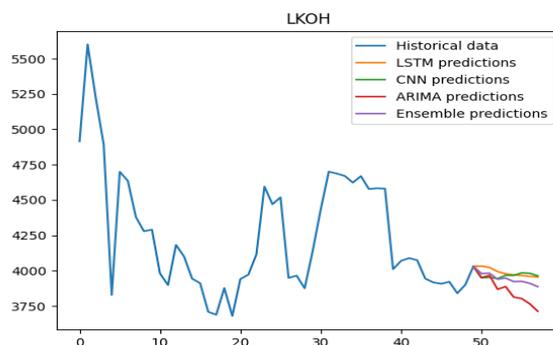


Рис. 5. Прогноз значений цена актива AKRN

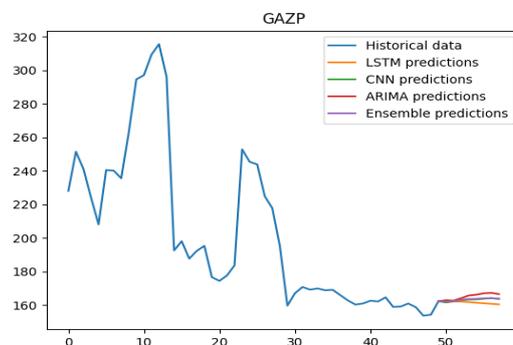


Рис. 6. Прогноз значений цены актива GAZP

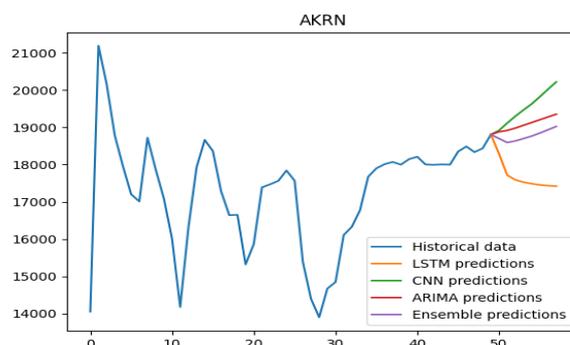


Рис. 7. Прогноз значений актива LKOH

Таблица 1. Сравнительный анализ метрик RMSE

Метод/Акция	AKRN	GAZP	LKOH
LSTM	331.4302	10.2008	153.7553
CNN	441.7779	10.3395	170.7299
Arima	372.3841	10.6302	162.2414
Ансамбль	350.0852	10.0689	159.1296

Основываясь на полученных результатах, можно сделать вывод, что различные модели по-разному работают с разными данными. В то время как метод ансамбля, хорошо зарекомендовал себя на акциях "Газпрома", у LSTM была наименьшая ошибка на остальных акциях. Arima также показала неплохие результаты, однако не самые лучшие. CNN в свою очередь дали неплохие результаты по акции "Газпром", однако на других акциях они показали наихудшие результаты среди других методов.

3. Заключение

В настоящее время прогнозирование временных рядов становится все более важным в различных сферах человеческой деятельности, так как позволяет предсказать поведение различных факторов. В результате проведенного исследования было установлено, что LSTM, а также ансамблевый метод наиболее эффективные инструменты прогнозирования временных рядов. Однако, важно тщательно подбирать правильный алгоритм для каждой конкретной задачи, учитывая ее специфику.

Литература

1. *Иванюк В.А.* Методика долгосрочного прогнозирования на основе мультитрендового прогноза / Мягкие измерения и вычисления. – 2023. – Т. 73. – № 12. – С. 128–138
2. *Иванюк В.А.* Нейросетевое моделирование в экономике и финансах //Управление развитием крупномасштабных систем MLSD'2020. – 2020. – С. 828-831.
3. *Иванюк В. А.* Нейронные сети и их анализ //Хроноэкономика. – 2021. – №. 4 (32). – С. 56-59.
4. *Андрянов Н.А., Петросов Д.А., Поляков А.В.* Выбор архитектуры искусственной нейронной сети для оценки состояния популяции генетического алгоритма в задаче структурно-параметрического синтеза имитационных моделей бизнес-процессов / Мягкие измерения и вычисления. 2023. Т. 73. № 12. С. 70-81.
5. *Петросов Д.А., Андрянов Н.А., Алюнов А.Н., Нежданов Е.В.* Представление данных о состоянии популяции и обучение искусственной нейронной сети в задаче управления работой генетическим алгоритмом / Экономика. Информатика. 2023. Т. 50. № 4. С. 924-935.